

画像セグメンテーションを用いた屋根面分割による 屋根損傷率自動算出手法の開発

藤田翔乃¹ 畑山満則^{†1}

概要：災害が起こった際、自治体は被災した住家の被害の程度を調査し、被災者に罹災証明書を交付する。罹災証明書は被災者の支援策の判断材料として活用され、生活再建に必要不可欠であるため、自治体は迅速かつ正確に発行しなければならない。しかし、これまでの地震災害では被害認定調査・罹災証明書発行に多くの時間を要しており、円滑な被災者支援を妨げていた。加えて現在の屋根調査においては、屋根全てを見渡すことができず、正確に屋根調査を行えていない。そこで、本研究では航空写真から自動で屋根損傷率を算出する画像処理モデルを開発した。筆者らの先行研究から得た学習データの不足という問題に対して、本研究は真相学習による画像セグメンテーションを用いて屋根画像を屋根面で分割して学習データを増加させるという方法をとった。その結果、30%のデータを従来の現地調査員による判定より高い精度で、80%のデータを従来判定以上の精度で屋根損傷率を算出できることがわかった。

Development of Automatic Method to Calculate Damage Rate of Roof by dividing Roof Image into Sections by Image Segmentation

SHONO FUJITA¹ MICHINORI HATAYAMA^{†1}

1. 研究背景と目的

1.1 被害認定調査における問題

地震や風水害等の災害が起こった際、自治体は被災した住家の被害の程度を調査し、被災者に住家が被災したことを証明するものとして、罹災証明書を交付する。罹災証明書は被災者の各種支援策の判断材料として活用され、生活再建に必要不可欠であるため、自治体は迅速かつ正確に発行しなければならない[1]。東日本大震災の後に災害対策基本法が改定され、罹災証明書を遅滞なく発行することが義務付けられた[2]。しかし、これまでの地震災害では被害認定調査・罹災証明書発行に多くの時間を要しており、円滑な被災者支援を妨げていた。

また部位による判定の一つである屋根被害調査において、屋根全てを見渡すことができず、遠くから見ると地上から見える範囲で調査を行なっている。加えて、屋根面ごとに損傷程度を算出する必要があり、高度な専門的知識を要する。地上から見ることはできないという調査方法に加え、専門的知識を有しない調査員からすると正確に屋根調査を行うことは非常に困難であり、多くの時間を要する。

1.2 災害時の航空写真の利用

2016年4月に発生した熊本地震の後、内閣府は平成30年3月に「災害に係る住家の被害認定基準運用指針」と「実施体制の手引き」の改定を行い[3]、「航空写真等を活用して『全壊』の判定が可能」を明記したことから、航空写真の積極的な利用を促進していることがわかる。

また、災害時には多様な行政機関や研究機関が航空機やドローンを利用して航空写真の撮影を行なっている。国土地理院は被災地域の航空写真を撮影し、初動対応や被災状況の把握、応急復旧、復興のための重要な資料としている[4]。特定非営利活動法人クライシスマップーズ・ジャパンでは、災害ドローン救援隊「DRONE BIRD」という組織を運営しており、ドローンで撮影した航空写真から人命救助などの支援活動を行なっている[5]。よって、災害時にはこれらの機関により航空写真データを利用できることがわかる。

1.3 研究目的

上記の研究背景から、本研究では従来の現地調査員による判定以上の精度で航空写真から屋根損傷率を自動算出する画像処理モデルを開発する。これにより迅速かつ正確な屋根被害調査が行われることが期待される。

¹ 京都大学大学院 情報学研究科
Graduate School of Informatics, Kyoto University
Kyoto 606-8501, Japan

^{†1} 京都大学 防災研究所
DPRI, Kyoto University
Kyoto 611-0011, Japan

2. 先行研究

松岡らの研究[6]では、赤外線カメラ搭載 UAV の赤外線画像における色の特徴により被害箇所と無被害箇所の判別を行った。釜ヶ谷・松岡の研究[7]では、ラインセンサと呼ばれる航空カメラで真上から撮影した航空写真と斜めから撮影した航空写真から深層学習を用いて被害の程度のカテゴリ推測を行った。本研究では、上記の研究のような特殊な航空写真ではなく、比較的安価で飛行が容易な航空機やドローンなどからの航空写真を用いる。これにより、容易に学習データの増加や、災害時の推測データの取得を行うことができる。また、航空写真から一つ一つの建物のデータを取得する際、上記の研究では一枚一枚人の手によって建物が収まるように画像を切り出して作成している。本研究では地理空間情報の建物ポリゴンの位置情報を用いた独自のトリミングアルゴリズムにより、自動で建物の画像を切り出してデータを作成する。

Jiら[8]は発災前後の航空写真の差分情報からテキスト解析と CNN により特徴を抽出し、ランダムフォレストを利用して被害建物を推測した。これは被害のあった建物の屋根の変化が発災前後の航空写真の差分情報として現れることを利用している。しかし被害のあった地域において、発災前の航空写真の撮影時期が古く、建物の情報が発災時と大きく異なる可能性がある。この場合差分がある建物には、被害がある建物だけではなく新築の建物や取り壊しになった建物が含まれてしまう。本研究では、発災後の航空写真のみを利用するためこのような問題は生じないと考えられる。

利根川ら[9]は、被災瓦礫量推定のために東日本大震災で倒壊・流出した家屋を航空写真から深層学習を用いて推測を行なった。内藤ら[10]は災害対応を迅速化することを目的として、複数の地震における航空写真を用いて深層学習により木造建物の被災度を自動判別した。Miuraら[11]は航空写真から深層学習を用いて、倒壊建物とブルーシートがかかった建物を検出した。これらの研究により、災害時において被害建物を抽出するために、航空写真を用いた深層学習による画像認識が有効であることがわかる。しかし、これらは倒壊建物や建物全体の被害を判定したものであり、屋根の損傷率を判定したものは存在していない。

3. 屋根損傷率自動算出手法の開発

3.1 被害認定調査における屋根損傷率算出手法

部位による判定では壁や基礎、屋根の損傷率を算定し、それらの合計から建物の被災度を決定する。この屋根の損傷率は式(1)のように、屋根面ごとに損傷程度と面積割合をかけ、それを全ての屋根面で足し合わせることで算出される。損傷程度は、損傷の種類や損傷箇所により百分率で表される。同一屋根面内で損傷程度が異なる部分が存在する場合は面積の加重平均で損傷程度が求められる。

$$\text{損傷率} = \sum_i \frac{\text{屋根面の面積}}{\text{全体屋根面積}} \times \text{屋根面の損傷程度} \quad (1)$$

3.2 本研究における屋根損傷率算出手法




図1 屋根損傷率算出のフロー

図1に本研究の屋根損傷率算出手法のフローを示す。本手法では、トリミング、屋根面分割、損傷程度分類、損傷率算出の4つの処理を行い、屋根損傷率を自動で算出する。

3.3 トリミングアルゴリズム




図2 トリミングアルゴリズム




図3 ピクセルの内外判定

トリミングアルゴリズムでは、航空写真と地理空間情報である建物ポリゴンの頂点の位置情報を用いることで、図2のように屋根画像データを自動で作成することができる。これは図3のように航空写真の各ピクセルを建物ポリゴン内にあるか外にあるかの内外判定を行い、内にあるピクセルの色はそのまま、外にあるピクセルは黒色とすることで実装することができる。対象とするピクセルから半直線を伸ばし、その半直線とポリゴンとの交点の数が奇数である場合は内、偶数である場合は外であると判定することができる。

トリミングにより航空写真から一つ一つの建物を切り抜くことから、画像データを作成する時間を削減することができ、迅速に推測することが可能となる。加えて大量の学習データを作成することができる。また、建物ポリゴンを利用していることから、エリア・メッシュ単位での推測ではなく、建物単位での推測を行うことができ、より詳細な情報を得ることができる。利根川ら[9]、内藤ら[10]、Miuraら[11]の先行研究でも同様に建物ポリゴンを利用して、画像データを作成している。しかし、目的が建物全体の被害検出であるため、建物ポリゴンの外接四角形を利用するなどしてポリゴンの外の情報も画像データに含んでいる。本

研究では図3のような方法を用いて屋根以外の部分を黒く塗ることで、屋根損傷率算出に不要な地上部分などの情報を排除でき、精度向上が期待できる。

3.4 深層学習における課題

筆者らの先行研究[12]において、同様にトリミングした屋根画像から深層学習を用いて損傷部分の有無とブルーシートの有無の判別を行った。損傷部分判別の精度が **balanced accuracy** が 75.58%, 再現率が 67.50% であり、ブルーシートの **balanced accuracy** が 93.16%, 再現率が 93.49% であった。ここで **balanced accuracy** は2クラスの再現率の平均を表す。損傷部分判別において両方の値が低いという結果に対して、特徴抽出が困難であったこと、利用していた航空写真データがドローンではなく航空機による写真であったことが原因であると結論づけた。深層学習モデルの精度を向上させるには学習データを豊富に利用することが必要である。しかし、地震災害により損傷を受けた屋根を映した高画質な航空写真は豊富に存在しない。この理由としては、地震災害の頻度が低いこと、高画質な航空写真データを撮影できるドローンの開発からまだ日が浅いこと、ブルーシートがかかる前に撮影を行わなければならないという時間的制約が存在することなどが挙げられる。したがって、災害時の航空写真から深層学習を行う本研究の課題として、精度向上に必要な学習データが豊富には存在しないということが考えられる。

3.5 屋根面分割によるデータ増加

上記の課題を踏まえ、本研究では図1のようにトリミング屋根画像を屋根面で分割し、学習データを増加させるという方法をとる。一つのトリミング屋根画像から複数の屋根面画像を作ることにより、数倍の数の屋根損傷画像の学習データを得ることができる。そして、分割された屋根面画像は損傷程度分類モデルへ入力され、損傷程度が推測される。その値と面積割合をかけ、各屋根面で足し合わせることで最終的な屋根ごとの損傷率を算出することができる。

Iseら[13]は画像中のコケに識別のために、画像を細切れにした学習データを利用して深層学習を行うことを提案し、高い精度をもたらした。これにより、一枚の画像から多量の学習データを生成することが可能になるだけでなく、形状が不安定な対象物についても深層学習により分類を行うことができることがわかった。また、分割することは画像内の損傷部分を大きくすることができ、検出をより容易にさせることができると考えられる。そして、分割された画像はサイズが小さくなっており、保持する情報量も小さくなっているため、後の損傷程度分類モデルに必要なパラメータ数を削減できると考えられる。被害認定調査の観点からは、この本研究の手法は実際の調査手法に沿っており近い算出結果が期待できるほか、被災者の推測数値に対する懐疑心も軽減されることが考えられる。

4. 屋根面分割

4.1 屋根抽出に関する先行研究

Susaki[14]は、輝度値を少数個の値に離散化し、長方形に近い領域を優先的に抽出し、屋根領域を分割した。この時、離散化の幅を複数用意することで、影を持つなどの輝度値の分散が大きいテクスチャを持つ屋根でも対応することができた。しかしこれは屋根面ではなく、一つの建物の屋根を抽出するものであるため、長方形に焦点を当て屋根と認識している。屋根面を分割する際、長方形以外の形の領域も抽出する必要がある。また、このような色・テクスチャ情報から抽出を行う方法では、地震災害による損傷や屋根面上の汚れなど不規則な部分が存在する場合、誤って一つの屋根面であると認識する恐れがある。以上のようなことから、本研究では形や色、テクスチャ情報だけではなく、より複雑の特徴から、様々な形の屋根を抽出できる深層学習の **segmentation** モデルによる屋根面抽出・分割を行う。**Segmentation** モデルとは画像内の物体ごとの領域を抽出するものであり、これを利用することで屋根面を抽出・分割することができると考えられる。

4.2 Segmentation モデル




図4 semantic segmentation による屋根面分割




図5 Mask R-CNN の構造

深層学習を用いた **segmentation** モデルは **semantic segmentation** モデルと **instance segmentation** モデルの二種類が存在する。どちらの **segmentation** モデルとも画像内の各ピクセルのクラスを分類し領域を抽出するが、**semantic segmentation** は画像内の同クラスの物体を個別に認識することができない。深層学習を用いた **semantic segmentation** モデルの一つである **deplab V3 plus**[15]を利用し屋根面分割

を試みたが、図 4 のように屋根面同士が結合し一つの屋根面となった。このように semantic segmentation では隣接する屋根面を個別に認識することができず、一つの屋根面として抽出されてしまう。よって instance segmentation を利用する必要があることがわかる。

本研究は、深層学習を用いた instance segmentation モデルのうち Mask R-CNN[16]を利用する。これは世界的な画像コンペティションである 2016 年の COCO challenge において、instance segmentation, bounding-box object detection, person key point detection の 3 つのタスクで優勝したモデルである。Mask R-CNN のモデルを図 5 に示す。このモデルでは、まず畳み込み層である convolutional backbone 層から特徴を抽出し、feature map を得る。次に畳み込み層である RPN(Region Proposal Network) 層で物体らしい領域 RoI(Region of Interest)の外接四角形を得る。Feature map から RoI の領域を抽出し、固定されたサイズに変換を行う。その抽出・サイズ変換した領域を畳み込み層である mask branch に入力し、ピクセルごとに物体か背景を分類する。同時に抽出・サイズ変換した領域を全結合層に入力し、物体領域の誤差とクラス分類の結果を得る。最後に全結合層のクラス分類結果と、mask branch の物体に分類したピクセルから画像内の物体領域を抽出することができる。このモデルはクラス分類タスクと segmentation タスクを分けることで計算量を削減し、精度を向上させている。

4.3 利用するデータ

学習データとして、熊本地震後の益城町付近の航空写真から基盤地図情報の建物ポリゴンを用いてトリミングした屋根画像を利用した。この航空写真はドローンではなく、航空機によるものであり解像度は 20cm 分解能である。そして、このトリミング屋根画像にアノテーションツール「labelme」を用いて、屋根面領域のラベルを入力した。その入力時間はおおよそ屋根画像一枚につき、約 1 分であり、合計 8~9 時間の時間を要した。パラメータ更新のための学習データとして 2400 枚(300×8)、過学習確認のための検証データとして 800 枚(100×8)、モデルの精度評価のための評価データとして 800 枚(100×8)のトリミング屋根画像を用いた。それぞれ、元の画像に対して左右反転、90 度・180 度・270 度回転をさせて 8 倍にデータ数を増加させた。損傷のある屋根画像にもモデルを対応させ、評価するために、学習データ・検証データ・評価データそれぞれに屋根損傷のある画像データを含ませた。建物ポリゴンと実際の建物の位置は多少のずれが生じており、大きくずれている屋根画像と人の目で屋根面が判断できない画像に関してはこれらのデータから排除した。

4.4 学習概要

あらかじめ COCO データセットで学習させたモデルに対して、トリミング屋根画像、屋根面領域のラベルを用いて再度学習を行う fine tuning を行なった。一般的に学習を




図 6 損失関数の推移(左：初期実験，右：追加実験，橙線-学習データ，青線-検証データの移動平均)

行いすぎると学習データに特化したモデルとなり、汎化性能を失い、精度が低下する。そこで、検証データでモデルの損失関数を確認し、それが増加した時を過学習とみなし、学習を止めた。本実験の損失関数は、RPN の RoI の位置のずれによる損失関数、RPN の RoI の物体か背景の分類による損失関数、最終全結合層の物体領域の位置ずれによる損失関数、最終全結合層のクラス分類による損失関数、mask branch の物体か背景かクラス分類による損失関数の合計である。分類クラスは屋根か背景かの 2 クラス、入力の画像サイズは 256×256、バッチサイズは 2、1 エポックあたりのステップ数は 100、検証データの損失関数計算のステップ数は 5 であった。また、GPU として NVIDIA 社の Tesla K40c と GeoForce GTX 1060 6GB を利用し、1000 エポックの学習を 16 時間 4 分かけて行なった。学習データと検証データの損失関数の推移を図 6 左に示す。損失関数の推移からエポック 500 あたりから上昇が見られたので、エポック 500 で学習を止めたモデルを利用した。

4.5 初期実験の分割結果

表 1 初期実験の分割結果

初期実験	全体	屋根面内 損傷画像	屋根面境界 損傷画像	木の葉が 映った画像
平均IoU	0.7580	0.7341	0.6874	0.7237
平均AP	0.6670	0.6846	0.5752	0.3979




図 7 IoU と AP のヒストグラム

その結果は表 1 の初期実験が示すように画像ごとの平均 IoU が 0.7580、平均 AP が 0.6670 であり、そのヒストグラムは図 7 のようになった。ここで IoU とは正解領域と推測領域の重なり具合を示すものであり、積集合を和集合で割った値である。各画像が持つ複数の推測領域の IoU の平均を求め、さらに画像ごとのその平均をとった。また、AP とは画像ごとで求められる推測の適合率と再現率の高さを表す指標である。

インスタンス平均 IoU・AP が高かった画像を図 8 左に、




図 8 左：屋根面内に損傷がある屋根画像，
右：屋根面境界に損傷がある屋根画像，
それぞれ左から元画像，正解ラベル，モデル推測

インスタンス平均 IoU・AP が低かった画像を図 8 右に示す．平均 IoU・AP が高かった画像を見ると屋根面の領域が大きく，領域数が少ない傾向にあることがわかる．逆に平均 IoU・AP が低かった画像を見ると屋根面の領域が小さく，領域数が多い傾向にあり，隣接する屋根面の色の差が小さいなど境界線が薄い画像も多かった．また，複数の推測領域が重なる部分が存在すること，推測されていない見逃し領域が多くあることがわかった．

4.6 特徴を持つ屋根画像




図 9 左：根面内に損傷がある屋根画像，
右：屋根面境界に損傷がある屋根画像，
それぞれ左から元画像，正解ラベル，モデル推測




図 10 木の葉が映った屋根画像
左から元画像，正解ラベル，モデル推測

図 9 のような損傷部分を持つ屋根画像に着目すると，屋根面内に損傷がある画像(図 9 左)と屋根面境界部分に損傷がある画像(図 9 右)で屋根面分割の精度が異なっていることがわかった．屋根面内に損傷がある画像 40 枚(元画像は 5 枚)では，表 1 が示すように平均 IoU が 0.7341，平均 AP

が 0.6846 であった．全ての画像の平均と比較すると IoU は 0.0239 低く，AP は 0.0176 高くなっていたことから，屋根面内に損傷がある画像はその他の屋根画像とほとんど同等の精度で屋根面分割を行えたと言える．つまり，損傷などによる屋根面内の色や模様が不連続であっても，正確に屋根面分割を行えていることから，深層学習の instance segmentation 利用が有効であったと言える．屋根面境界部分に損傷がある画像 40 枚(元画像は 5 枚)では，表 1 が示すように平均 IoU が 0.6874，平均 AP が 0.5752 であった．全ての画像の平均と比較すると IoU が 0.0706，AP が 0.0918 低くなっていたことから，屋根面境界部分に損傷がある画像はその他の屋根画像と比較すると，正確な屋根面分割が行えていないことがわかる．また，平均 IoU・AP が低い画像の中には上述した特徴を持つ屋根だけではなく，図 10 のように木の葉が映った屋根が多いことがわかった．表 1 が示すように，この木の葉が映った屋根画像 24 枚(元画像 3 枚)の平均 IoU が 0.7237，平均 AP が 0.3979 であり，全ての画像の平均と比較すると IoU が 0.0343，AP が 0.2691 低くなっていた．これは葉によって屋根部分が隠れてしまったことに加えて，葉の周り付近は屋根面ではなく庭や道路などの外の地面であると誤って認識していると考えられる．これは建物ポリゴンと実際の建物の位置にずれが生じ，学習データの一部で，屋根以外の外の地面部分が木の葉とともに多少映り込んだことが原因であると考えられる．このずれによって現れた葉の周り付近は外の地面であるため屋根と認識する必要はない．しかし，木の葉によって一部隠れてしまった本来屋根である部分付近もこの傾向により屋根と認識しなかったと考えられる．

4.7 追加実験の分割結果

表 2. 追加実験の分割結果

追加実験	全体	屋根面境界 損傷画像	木の葉が 映った画像
平均IoU	0.7672	0.6858	0.7074
平均AP	0.6934	0.6094	0.4628

以上のような特徴を持つ画像にも対処するために，学習データに屋根面境界部分に損傷を持つ屋根画像，木の葉によって隠れてしまった屋根画像をそれぞれ 160 枚(元画像は 20 枚)を新たに加え，学習データ 2720 枚，検証データ 800 枚，評価データ 800 枚で同様に学習を行った．図 6 の右のような損失関数の推移からエポック 600 あたりから上昇が見られたので，エポック 600 で学習を止めたモデルを利用した．その結果，表 2 が示すように全体の平均 IoU が 0.7672，平均 AP が 0.6934 となり，初期実験と比べて両方の値とも増加が見られた．表 2 が示すように，屋根面境界に損傷を持つ屋根画像 40 枚の平均 IoU は 0.6858，平均 AP は 0.6094 であり，初期実験と比べると平均 IoU は 0.0016 の減少が，平均 AP は 0.0342 の増加が見られた．木の葉が映

った屋根画像 24 枚の平均 IoU は 0.7074, 平均 AP は 0.4628 であり, 初期実験と比べると平均 IoU は 0.0163 の減少が, 平均 AP は 0.0649 の増加が見られた. 屋根面境界に損傷を持つ屋根画像, 木の葉が映った屋根画像とも, 両方の値の増加は見られなかったが, 両方の値の増減の差を考慮すると学習データの増加により, それらの画像においてある程度の精度上昇が起こったと考えられる.

4.8 分割後の画像処理

(1) 重なった部分の削除




図 11 重なる部分を持つ屋根画像
左から元画像, 正解ラベル, モデル推測,
モデル推測(重なり削除)

損傷部分の重複抽出, 面積割合の過大評価を防ぐために推測領域が重なる部分を削除する必要がある. どの推測領域が正しいかを選択し, それ以外の推測領域を排除することで重なる部分を削除することができる.

図 11 のような重なった部分を持つ屋根画像から, 面積が大きい領域が小さい領域にまで拡張しているものが多いことがわかった. そこで追加実験の推測の後, 重なった領域のうち面積割合が小さい領域を選択し, それ以外を排除して, 重なった部分を削除した.

(2) 見逃し部分の削除




図 12 見逃し領域を拡張した屋根画像
左から元画像, 正解ラベル, モデル推測,
モデル推測(重なり削除)

推測損傷部分の見逃し, 面積割合の過小評価を防ぐためにどの推測領域にも含まれていない屋根部分を削除する必要がある. そこで, 面積が小さい領域を選択する重なった部分の削除を行った後, 図 12 のように推測領域を拡張させることでその見逃し部分の埋め合わせを行った. 推測領

域の拡張では, 画像内の推測領域を同等の速さで四方に広げるようにアルゴリズムを作成した.

Instance segmentation により屋根面が分割され, 重なり部分の削除, 見逃し部分の削除の二処理を行った後, 図 13 のように屋根面個別の画像データを作成した. トリミング画像と同様に屋根以外の部分は黒色とした.




図 13 屋根面画像の作成例

5. 損傷程度分類

5.1 モデル概要

本研究では損傷程度分類モデルにおいても深層学習モデルの一つの ResNet50[17]を利用し, 屋根面ごとの損傷程度を推測するモデルを構築する. この ResNet は 2015 年の世界的画像認識コンテストの ILSVRC で優勝したモデルであり, 画像分類において高い精度を持つことで知られている. また ILSVRC とは 1000 クラスものカテゴリ进行分类するものであるため, ResNet は高い汎用性を持つモデルであると言える. 一般的に深層学習において, 層数が多いモデルは複雑な表現力を持ちうる[18]. しかし層数が多すぎる場合, 誤差逆伝播の際に損失関数の勾配が下層に伝わることができず, パラメーターの更新が行われない勾配消失が生じる. ResNet では residual モジュールというショートカットの層を追加させることで, 層数を増やしても勾配を消失させず下層に伝えることができる. また, 深層学習 API の一つである keras Applications では層数の違いによる複数の種類の ResNet を提供している[19]. 本研究は分類タスクが損傷程度に限定されていること, 屋根面分割により画像サイズが減少していることから, パラメーター数が最も少ない ResNet50 を利用する.

5.2 データ作成

屋根面分割により作成される屋根面画像データは, 解像度 20cm 分解能の屋根画像を分割したものであるため画質が荒く, 詳細に損傷程度を決定できるとは言えない. よって本研究では屋根面を被害なし, 被害あり(-25%), 被害あり(25-50%), 被害あり(50-75%), 被害あり(75%-)の 5 クラスに分類し, 損傷程度を推測するモデルを構築する. ここでは, 図 14 のようにデータを作成した. 評価データとして損傷がある屋根画像を 30 枚, 損傷がない屋根画像を 30 枚使用した. 損傷がある屋根画像 30 枚は, 多様な損傷程度の屋根面画像を入手するために大まかに被害程度のばらつきがあるように選択した. 損傷がある屋根画像に 4 章のモデルを利用して屋根面分割をし, それらの屋根面画像 208 枚に




図 15 入力の際の判断画像

対して実際に被害認定調査の経験がある高知県四十万十町危機管理課の職員に損傷程度ラベルの入力を行ってもらった。入力の際には図 15 のように、屋根面画像、その屋根面を色付けた屋根全体画像、屋根全体のみの画像の三つから判断を行ってもらった。学習データ・検証データとして、損傷がある屋根画像を 684 枚、損傷がない屋根画像を 500 枚使用した。この損傷がある屋根から分割された屋根面画像 4,392 枚に対して、評価データのラベルや損傷程度例[1]などを参考にし、筆者自らラベル入力を行った。その結果、損傷がある屋根画像 684 枚から合計 2,171 枚の損傷がある屋根面画像を作成したため、3.174 倍の学習データの増加を行うことができたと言える。図 14 のように、これらの学習データ・検証データに左右反転や回転を行い、クラス間のデータ数をほぼ同じにした。また被害なしのデータは、加えて多様な種類の屋根を持つように、一つの屋根からは一つの屋根面を選出するようにした。

また、筆者が行った学習データ・検証データ作成の際、約 24,000 枚の屋根画像から損傷がある屋根画像 684 枚を抽出するのに約 10 時間、そこから分割された屋根面画像 4,392 枚の損傷程度のラベルづけを行うのに約 12 時間の時間を要した。自治体職員が行った評価データ作成の際には、屋根面画像 208 枚に対して約 2 時間の時間を要した。

5.3 學習概要

上記のデータを用いて、バッチサイズ 16、入力画像サイズ 256×256 、損失関数として交差エントロピーを用いて ResNet50 を学習させた。このとき、ImageNet という大規模データセットであらかじめ学習をさせた ResNet50 モデルに再度学習を行う *fine tuning* を行なった。NVIDIA 社の




図 16 左：損失関数の推移，右：正解率の推移
 左橙線-学習データ損失関数，
 左青線-検証データ損失関数の移動平均，
 右青線-正解率の移動平均

GeoForce GTX 1060 6GB の GPU を利用して、200 エポックで 5 時間 56 分を要した。その損失関数、正解率の推移を図 16 に示す。ここで 1 エポックは全ての学習データを 1 回学習させる回数とし、274 回の学習を意味する。図 16 から、正解率が高いかつ損失関数が減少したエポック 150 のモデルを利用した。

5.4 推測結果

表 3 損傷程度分類の混同行列

		正解					
		被害なし	被害あり (-25%)	被害あり (25-50%)	被害あり (50-75%)	被害あり (75%)	
推測	被害なし	181	15	9	4	0	平均再現率
	被害あり(-25%)	42	29	19	6	6	
	被害あり(25-50%)	8	5	5	5	5	
	被害あり(50-75%)	6	1	3	3	1	
	被害あり(75%-)	5	2	4	4	4	
再現率		0.7479	0.5577	0.1250	0.1364	0.2500	0.3634

表 4 各クラスの推測割合

		正解				
		被害なし	被害あり (-25%)	被害あり (25-50%)	被害あり (50-75%)	被害あり (75-%)
推測	被害なし	0.7479	0.2885	0.2250	0.1818	0.0000
	被害あり(-25%)	0.1736	0.5577	0.4750	0.2727	0.3750
	被害あり(25-50%)	0.0331	0.0962	0.1250	0.2273	0.3125
	被害あり(50-75%)	0.0248	0.0019	0.0750	0.1364	0.0625
	被害あり(75%-)	0.0207	0.0380	0.1000	0.1818	0.2500

評価データを用いたモデルの推測結果は表3の混同行列のようになった。各クラスの再現率は被害なしが0.7479、被害あり(-25%)が0.5577、被害あり(25-50%)が0.1250、被害あり(50-75%)が0.1364、被害あり(75%-)が0.2500、平均再現率は0.3634となった。各クラスの再現率から、被害なしのデータより被害ありのデータ、特に被害あり(25-50%)、被害あり(50-75%)、被害あり(75%-)の再現率が低いことがわかる。また表4に、それぞれの混同行列の値を各クラスの実際のデータ数で割り、各クラスのデータがどのくらいの割合でどのクラスに予想されているかの割合を示す。これから被害の大きな屋根面である被害あり(25-50%)、被害あり(50-75%)、被害あり(75%-)のデータの損傷程度が過小評価されている傾向にあることがわかる。

図 17 に損傷程度が過小評価されてしまったデータ例を示す。これらの屋根面は、対象屋根面に瓦の崩れなどの損




図 17 被害が大きいが過小評価されたデータ
左から推測対象の屋根面画像,
全体屋根画像のうち推測対象屋根面が色付けされたもの,
全体屋根画像,
上正解:被害あり(75%-), 上推測:被害あり(-25%),
中正解:被害あり(50-75%), 中推測:被害なし,
下正解:被害あり(25-50%), 下推測:被害なし




図 18 被害がないが被害ありと推測したデータ,
左から推測対象の屋根面画像,
全体屋根画像のうち推測対象屋根面が色付けされたもの,
全体屋根画像,
上正解:被害なし, 上推測:被害あり(-25%),
中正解:被害なし, 中推測:被害あり(-25%),
下正解:被害なし, 下推測:被害あり(25-50%)

傷部分の面積は小さいが、屋根全体が大きく崩れているものや、対象屋根面に損傷部分のみが映っているものが多かった。これらは、評価データの損傷程度のラベル入力の際、対象の屋根面だけではなく他の屋根面などの情報を考慮して、判断が行われていたと思われる。したがって、屋根面だけの情報から学習、推測を行っているモデルが過小評価してしまっていると考えられる。またラベル入力の際、低画像の航空写真を使用していることから、ラベル判定基準として個人の主観が混入していると考えられる。したがって、これら過小評価されたデータに関しては学習データのラベル入力を行った筆者の判定傾向が、正解である評価データのラベル入力者の判定傾向と多少異なっていたことも、影響していると考えられる。

また、被害なしの屋根面画像のうち被害あり(-25%)と推測したデータを図 18 に示す。これらから、瓦屋根の光の反

射による表面のざらつき、建物ポリゴンのズレによる地面や外の物体、屋根境界にある別素材などを損傷と誤って推測してしまっていることがわかる。このように損傷部分と似た部分は多種多様に存在しているため、より多様な被害なし屋根面画像を学習データに追加することが精度向上に必要であると考えられる。

6. 損傷率算出

6.1 推測損傷率算出手法

本研究では第 5 章で分類推測した 5 クラスに対して、被害なしを 0、被害あり(-25%)を 0.125、被害あり(25-50%)を 0.375、被害あり(50-75%)を 0.625、被害あり(75%-)を 0.875 として損傷度を割り当て、面積割合をかけた値を全ての屋根面で合計することで屋根損傷率を算出する(式(1))。面積割合は、各屋根面のピクセル数を全体の屋根のピクセル数で割ることで求めることができる。ここで屋根面、全体の屋根のピクセルとは、トリミングを行い屋根ではないとされた部分である黒色のピクセル以外を指す。

6.2 正解誤差

屋根損傷率の正解ラベルを入手するために、屋根面の損傷程度ラベルと同様に四万十町危機管理課の職員の方に、図 14 の評価データのうち損傷のある屋根画像 30 枚に対して、被害認定調査における屋根損傷率の入力を依頼した。この屋根画像 30 枚の屋根ごとに入力された全体屋根損傷率と、第 5 章で述べた屋根面ごとに入力された損傷程度ラベルから本研究による上記の方法で屋根損傷率を算出した結果、それら二つの値の決定係数が 0.4226、相関係数が 0.9450、平均誤差が-9.482、平均絶対値誤差が 9.681 であった。この 2 つの損傷率の誤差を以下、「正解誤差」と呼ぶ。平均誤差から本研究の算出方法では損傷率を過小評価する傾向にあることがわかる。またそれら 30 枚の正解誤差と屋根面分割における平均 IoU の相関係数は 0.0356、AP の相関係数は-0.0409 であったことから、屋根面分割が正確に行われることと本研究による算出方法で誤差が出ることに相関関係はないと言える。したがって、正確に屋根面分割が行われたとしてもこの正解誤差、過小評価は生じてしまうと考えられる。

同じ人が同じ屋根の損傷率を求めたのにも関わらず、本研究の算出結果がこのような過小評価の傾向にあるのは、入力の段階で屋根面ごとの損傷程度ラベルが過小評価されているからであると考えられる。前述した通り図 15 のように、対象屋根面画像、対象屋根面が色付けされた全体画像、全体画像の三つから入力の判断をしてもらった。このとき対象屋根面画像の端に損傷が現れた場合や周りの損傷情報から損傷程度が判断される場合などに、正しいラベル入力が困難であったと考えられる。

逆にモデルが誤った屋根面分割をしたとしても、正解誤差、過小評価の増加をもたらさないと言える。これは 4.8 の

分割後の処理において、損傷部分、その他屋根面部分の重複、見逃しを防いだことで、全体として損傷程度と面積割合が一定に保たれたためであると考えられる。しかしより説明性があり被災者に納得してもらえるモデルを構築するには、損傷している屋根面が把握できたり、実際の損傷率算出手法に近づけたりするために、高い屋根面分割精度が必要であることを留意すべきである。

6.3 正解損傷率と推測損傷率の比較




図 19 正解損傷率と推測損傷率の散布図




図 20 推測損傷率と正解損傷率の誤差のヒストグラム、左:損傷がある屋根データ、右:損傷がない屋根データ

第 5 章で分類推測した損傷がある屋根画像 30 枚、損傷がない屋根画像 30 枚の合計 60 枚に対して、屋根面ごとに分類推測された損傷程度から上記の方法で全体の屋根損傷率を推測した。その結果、正解損傷率と推測損傷率の決定係数は 0.3445、相関係数は 0.6486、平均誤差は-5.401、平均絶対値誤差は 11.07 であり、散布図は図 19 のようになった。また損傷があるデータにおいて平均誤差は-13.44、誤差のヒストグラムは図 20 左、損傷がないデータにおいて平均誤差は 2.641、誤差のヒストグラムは図 20 右となった。

損傷がある屋根データに関して、平均誤差と誤差のヒストグラムから、モデルは過小評価していることがわかる。これは、5.4 の損傷程度分類の際の過小評価と、6.2 のラベル入力段階の過小評価が影響していると考えられる。

損傷がない屋根データに関して、誤差のヒストグラムから多くは、損傷率数%で損傷していると推測しており、完全に損傷率 0%と推測したのは 30 枚中 12 枚であった。これは、損傷程度分類推測の際、分割した数個の屋根面のうち一つでも被害ありと推測してしまうと、全体の損傷率も被害があるように算出してしまうためである。この誤りに対しては、損傷程度分類モデルの被害なしの再現率を上げなければならないと考えられる。

誤差が大きかった屋根データを図 21 に示す。左から 4 つ目の推測損傷程度の可視化画像と、5 つ目の正解損傷程度の可視化画像では、被害あり(-25%)を黄緑色、被害あり(25-50%)を黄色、被害あり(50-75%)を橙色、被害あり(75%-)を赤色として色付けている。これから各屋根面で損傷程度の誤差が生じてそれらが積み重なった場合大きな誤差が生じているものが多かったことがわかる。また、屋根面分割において誤って大きく分割してしまった領域、もしくはそもそもの面積割合が大きい領域に対して、加えて損傷程度分類推測においても誤った推測を行うと、大きな誤差が生じてしまったデータも存在した。




図 21 推測損傷率の誤差が大きかった画像データ、左から元画像、正解屋根面領域、推測屋根面領域、正解損傷程度可視化画像、推測損傷程度可視化画像
上から正解損傷率:70%、推測損傷率:15.88%、
正解損傷率:54%、推測損傷率:9.994%、
正解損傷率:38%、推測損傷率:7.645%、
正解損傷率:0%、推測損傷率:23.93%

6.4 モデルの精度の評価

表 5 モデルの精度評価結果

回答項目	航空写真と地上から判断した調査員と同等	地上から判断した調査員より高い	地上から判断した調査員と同等	地上から判断した調査員より低い	合計
精度はどの程度か	15(25.00%)	3(5.000%)	30(50.00%)	12(20.00%)	60

四万十町危機管理課の職員の方に本モデルが推測した屋根画像 60 枚に対して、精度の評価を行ってもらった。

モデルの精度を評価する際、地上から屋根を見たときの調査員の精度、航空写真と地上から見たときの調査員の精度と定量的に比較するのが望ましいが、そのようなデータを作成、入手することは極めて難しい。よってモデルの推測損傷率の精度を、「航空写真と地上から判断した調査員と同等」、「(前述未満)地上から判断した調査員より高い」、「(前述未満)地上から判断した調査員と同等」、「地上から判断した調査員より低い」の四つの区分に分類してもらい、定性的に評価を行った。その結果は表 5 が示すように、「航空写真と地上から判断した調査員と同等」が 25.00%、「(前

述未満)地上から判断した調査員より高い」が 5.000%,「(前述未満)地上から判断した調査員と同等」が 50.00%,「地上から判断した調査員より低い」が 20.00%であった。よって本研究により, 30.00%の屋根が従来の地上から調査する方法より高い精度で損傷率を算出することができると言える。また, 80.00%の屋根が従来の地上から調査する方法と同等, もしくはそれより高い精度で損傷率を算出することができると言える。

図 22 にこの回答別の推測損傷率の誤差の箱ひげ図を示す。これから「航空写真と地上から判断した調査員と同等」と「(前述未満)地上から判断した調査員より高い」の屋根はおおよそ誤差 10%以下であり,「(前述未満)地上から判断した調査員と同等」の屋根はおおよそ誤差 20%以下,「地上から判断した調査員より低い」の屋根はおおよそ誤差 20%以上であることがわかる。これらの箱ひげ図の各数値や平均が, 回答された四つの精度分類に対して単純に増加傾向にないのは, 対象建物の周囲の状況や屋根の構造により, 比較対象である地上から判断した調査員の精度が変化するためであると考えられる。




図 22 回答別の推測誤差の箱ひげ図,
(“=photo and ground”は航空写真と地上から判断した調査員と同等, “>ground”は(前述未満)地上から判断した調査員より高い, “=ground”は(前述未満)地上から判断した調査員と同等, “<ground”は地上から判断した調査員より低い, を示す)

7. まとめと今後の課題

本研究では, 航空写真から被害認定調査における屋根損傷率を自動算出することを目的として, トリミング・屋根面分割・損傷程度分類・損傷率算出の 4 つの処理からなる画像処理モデルを開発した。筆者らの先行研究[20]から得た課題である, 災害時の学習データの不足に対して, 本研究では instance segmentation を用いた屋根面分割を行い, 学習データを増加させる方法をとった。

屋根面分割において, 損傷などによる屋根面内の色や模

様が不連続であっても, 正確に屋根面分割を行えたことから, 深層学習の instance segmentation 利用が有効であったことがわかった。また, 間違いやすい屋根画像を学習データに追加することで, ある程度の精度上昇が起こった。しかし平均 IoU, AP 両方の値をより増加させるには, モデルが間違いやすいデータをさらに見つけ, 学習データを量・質ともにより豊富にしなければならない。

損傷程度分類では, 平均再現率が 0.3634 であり, 課題点が多く見られた。対象屋根面だけではなく全体の屋根の情報などをモデルの入力値として利用して過小評価を防ぐことや, 複数のラベル入力者による学習データ作成から汎用的なモデルを構築することが必要であることがわかった。

損傷率算出では, 入力の段階で入力ラベルの過小評価が生じていることがわかり, より工夫された入力方法が必要であることがわかった。これらの過小評価により, 被害のある屋根画像の推測損傷率にも同様に過小評価が生じていることがわかった。また, 被害のない屋根画像を正確に判定するには, 損傷程度分類の際の被害なし屋根面の再現率を増加しなければならないことがわかった。

調査経験のある自治体職員による精度評価では, 30.00%の屋根を従来の地上から調査する方法より高い精度で損傷率を算出することができ, 80.00%の屋根が従来方法と同等, もしくはそれより高い精度で損傷率を算出することができた。このことから, 本モデルにより従来の現地調査員による判定以上の精度で航空写真から屋根損傷率を自動算出することができたと言える。

今後は上記のような課題に加えて, 建物ポリゴンが大きくずれている, または画質が悪いなどの理由から排除された屋根画像にも対応できるような, 高い精度を持つモデルを開発しなければならない。

謝辞 高知県四万十町危機管理課の川上様によりデータ入力を行っていただきました。この場を借りて深く御礼申し上げます。

参考文献

- [1] 内閣府(防災担当).災害に係る住家の被害認定基準運用指針,2020
- [2] 内閣府(防災担当).災害に係る住家被害認定業務実施体制の手引き,2017
- [3] 内閣府:平成 30 年 3 月改定の概要,
<http://www.bousai.go.jp/taisaku/pdf/h3003kaitei.pdf>, (参照 2021-5-10).
- [4] 国土交通省 国土地理院.空中写真|国土地理院,
<http://www.gsi.go.jp/gazochosa/gazochosa41006.html>, (参照 2021-5-10).
- [5] DRONEBIRD.災害ドローン救援隊 DRONEBIRD| クライシス・マップーズ・ジャパン, <https://dronebird.org/>, (参照 2021-5-10)
- [6] 松岡佑樹, 藤生慎, 高山純一, 中山晶一郎, 須田信也, 坂口博紀.小型無人機に搭載した赤外線カメラにより取得される被災地画像データを用いた地震災害直後の建物被害把握, 第 55

回土木計画学研究発表会・講演集 pp.1-4

- [7] 釜ヶ谷悠馬, 松岡昌志. 2016 年熊本地震後の空中写真を用いた深層学習による建物被害分類, 東濃地震科学研究所報告「防災研究委員会 2017 年度報告書」, No.41, pp.49-57, 2017.
- [8] Min Ji, Lanfa Liu, Runlin Du and Manfred F. Buchroithner. A Comparative Study of Texture and Convolutional Neural Network Features for Detecting Collapsed Buildings After Earthquakes Using Pre- and Post- Event Satellite Imagery, Remote Sens. 2019, 11, 1202.
- [9] 利根川凜, 飯塚博幸, 山本雅人, 古川正志, 大内東. 被災がれき量推定に向けた畳み込みニューラルネットワークを用いた倒壊建造物の自動抽出, 情報処理学会論文誌, Vol.57, No. 6, pp.1565-1575, 2016
- [10] 内藤昌平, 友澤弘充, 森悠史, 門馬直一, 中村洋光, 藤原広行. 複数の地震における航空写真を用いた深層学習による建物被害判別モデルの開発, 日本地震工学会論文集, 2020 年 20 巻 7 号, p.7_177-7_216
- [11] Miura, H, Aridome, T, Matsuoka, M. Deep Learning-Based Identification of Collapsed, Non-Collapsed and Blue Tarp-Covered Buildings from Post-Disaster Aerial Images. Remote Sens. 2020, 12, 1924.
- [12] 藤田翔乃, 畑山満則. 航空写真を用いた深層学習による地震災害時の屋根損傷家屋の把握, 土木計画学研究・論文集第 37 巻, 2020 年 75 巻 6 号 pp.1_127-1_135
- [13] Takeshi Ise, Mari Minagawa, Masanori Onishi. Classifying 3 Moss Species by Deep Learning, Using the “Chopped Picture” Method, Open Journal of Ecology, 2018, 8, pp.166-173
- [14] Junichi Susaki. Segmentation of Shadowed Buildings in Dense Urban Areas from Aerial Photographs, Remote Sensing, vol.4, pp.911-933, 2012
- [15] Liang-Chieh Chen, Yukun Zhu, George Papandreou, Florian Schroff, Hartwig Adam. Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation, In ECCV, 2018
- [16] Kaiming He, Georgia Gkioxari, Piotr Dollar, Ross Girshick. Mask R-CNN, arXiv:1703.06870, 2017.
- [17] He, K., Zhang, X., Ren, S., Sun, J. Deep residual learning for image recognition. arXiv preprint arXiv:1512.03385, 2015.
- [18] 岡谷貴之. 画像認識のための深層学習の研究動向—畳み込みニューラルネットワークとその利用法の発展—, 特集「ニューラルネットワーク研究のフロンティア」, pp.171
- [19] Keras Applications : Keras Applications, <https://keras.io/api/applications/>, (参照 2021-5-10)